

전원왜란의 인지와 분류를 위한 웨이블릿을 기반으로 한 뉴럴네트워크 시스템

김홍균, 이진목, 최재호
 충북대학교 전기전자 컴퓨터공학부

A Wavelet-Based Neural Network System for Power Disturbance of Recognition and Classification

Hongkyun Kim, Jinmok Lee, Jaeho Choi
 School of Electrical and Computer, Chungbuk National University

Abstract - This paper presents a wavelet-based neural network technology for the detection and classification of the short durations type of power quality disturbances. Transients happen during very short durations to the nano- and microsecond. Thus, a method for detecting and classifying transient signals at the same time and in an automatic combines the properties of the wavelet transform and the advantages of neural networks. Especially, the additional feature extraction to improve the recognition rate is considered. The configuration of the hardware of TMS320C6711 DSP based with 16 channel 20Mhz sampling rate A/D(Analog to Digital) converter and some case studies are described.

1. 서 론

전력품질(PQ) 문제를 검출하는 방법으로는 신호의 크기와 반복주기 횟수를 이용하여 판단하는 RMS기법과 주파수로 분석하는 방법이 있다.

이중 주기가 긴 Sag, Swell, Interruption 등은 간단한 논리 비교로 판단이 용이하나 Harmonic 및 Noise, Transient 등 빠른 주기와 기본 주파수 성분을 와해시키는 형태의 전인파형 검출 및 분류는 많은 문제를 안고 있다. 이러한 신호들은 크기와 주기만으로는 판단이 불가능하므로 주파수 분석법이 사용되는데, 이것을 효과적으로 검출하기 위하여 주로 FFT 및 웨이블릿(WAVELET)을 이용한다^[1]. 특히 웨이블릿은 과도상태 해석에 탁월한 효과로 말미암아 많은 곳에서 다양한 용도로 활용되고 있다. 또한 검출된 신호를 분류하는 것으로는 다양한 형태의 지식기반 전문가 시스템이 사용되고 있지만, 본 논문에서는 이산웨이블릿변환(DWT)과 뉴럴네트워크(Neural Network)을 이용하여 신호를 검출하고 분류하였다. Transient 신호는 수 ns부터 수 μs의 매우 빠르고 짧은 주기를 갖는다. 하지만 이러한 문제들을 진단 하기 위해서는 고속 Sampling Rate의 A/D를 내장한 왜란신호검출용 하드웨어가 필요하다. 본 논문에서는 최대 20MHz 와 4MB의 버퍼를 각각 16 채널 내장한 시스템을 설계하여 실험에 응용하였다. 또한 분류를 위한 학습 자료로는 기존 논문들에 전원왜란

신호로 제시되었던 파형 및 현장에서 측정한 신호형태를 기반으로, 에질런트사의 임의 파형발생기(Arbitrary Waveform Generator)를 이용하여 그림 1 와 같은 형태의 왜란 파형을 생성하고 실험학습에 사용하였다^[2].

2. 본 론

2.1 검출알고리즘

웨이블릿 변환은 모함수의 이동과 스케일 변화를 이용하여 비정형신호를 분석하기 위한 수학적 이론으로 이산 웨이블릿 변환은 다음과 같이 정의된다.

$$\psi_{m,n}(k) = a_0^{-\frac{m}{2}} \psi(a_0^{-m}k - nb_0) \quad (1)$$

$$DWTx(m,n) = \sum_k x(k) \psi\left(\frac{k - nb_0 a_0^m}{a_0^m}\right) \quad (2)$$

함수 $\psi_{m,n}(k)$ 는 모함수로 $a = a_0^m$ 에 의해 팽창 수축 (scaling)을 하고, $b = nb_0 a_0^m$ 에 의해서 시간에 따른 이동(shifting)을 통해 신호를 해석하게 된다. 이때 a_0 와 b_0 는 0보다 큰 상수이다. 이산신호 $S[n]$ 을 $a_l[n] = S[n]$ 이라 하면 다해상도 분해는 저역통과필터인 $h[n]$ 와 고역통과필터인 $g[n]$ 에 그림 1에서와 같이 근사신호 (Approximation) $a_{l+1}[n]$ 과 세부신호(Detail) $d_{l+1}[n]$ 를 여러 번 반복연산을 통해 얻는 과정을 말한다. 이과정은 식 3, 4와 같으며 그림 2와 같이 나타낼 수 있다.

$$d_{l+1}[n] = \sum_k g[k - 2n] a_l[k] \quad (3)$$

$$a_{l+1}[n] = \sum_k h[k - 2n] a_l[k] \quad (4)$$




그림 1 뉴럴 학습을 위한 실험파형
 Fig. 1 Experiment signal for NEURAL NT




그림 2 다해상도 분해
Fig. 2 Multi-resolution signal decomposition

2.2 특징추출 알고리즘




그림 3 분석알고리즘 네트워크
Fig. 3 Network diagram of signal analysis algorithm

다층 퍼셉트론(Multi-layer Perceptron)은 입력층과 출력층 사이에 하나 이상의 중간층이 존재하는 신경망으로 그림 3과같이 입력층, 은닉층, 출력층 3방향으로 연결되어 있으며, 전방향(feed-forward)의 네트워크 구조를 갖는다. 학습알고리즘은 백프로파게이션을 사용한다. 이것의 기본원리는 다음과 같다. 입력층의 각 유니트에 입력패턴을 주면, 이 신호는 각 유니트에서 변환되어 중간층에 전달되고 출력층에서 신호를 출력하게 된다. 이 출력값과 기댓값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위층에서 역전파하여 하위층에 이를 근거로 다시 자기층의 연결강도를 조정해 나간다. 학습방법으로는 지도학습을 사용하는데 입력 및 원하는 목표출력이 네트워크에 제시된 후, 네트워크는 입력층에 주어진 패턴이 출력층에 전파되면서 변환된 출력을 목표패턴과 비교한다. 네트워크에서 출력된 패턴이 목표패턴과 일치 할 때까지 학습이 이루어진다. 그렇지 않은 경우는 얻어진 출력패턴과 목표패턴의 차이를 감소시키는 방향으로 네트워크의 연결강도를 조절하여 학습한다. 즉 p 번째의 입력 목표출력 패턴이 제시되는 경우에 노드 j 에서 노드 i 로의 연결강도 변화는 식 5와 같이 표현된다.

$$\Delta_p W_{ji} = \eta(t_{pj} - o_{pj})i_{pj} = \eta\delta_{pj}i_{pj} \quad (5)$$

- t_{pj} : p 번째 목표출력 패턴의 j 성분
- o_{pj} : 네트워크에서 계산한 출력의 j 성분
- i_{pj} : p 번째 입력 패턴의 j 성분
- $\delta_{pj} = t_{pj} - o_{pj}$: 목표출력과 실제출력의 오차
- $\Delta_p W_{ji}$: i 와 j 유니트의 연결강도 변화량

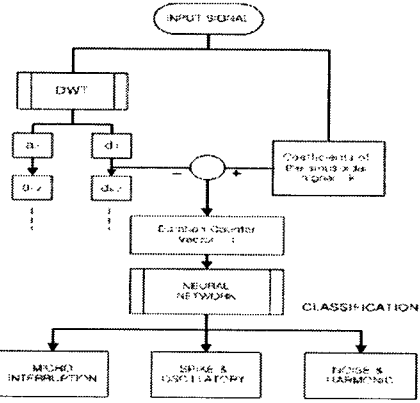


그림 4 신호분류 흐름도
Fig. 4 Flowchart of signal classification

전력품질의 입력값은 시간에 따라 변화하는 전압과 전류 값으로, 시간에 따른 전압의 크기 값 또는 위상의 변화로 나타난다, 전압의 일정크기 즉, $\pm 10\%$ 이상의 변동에서는 비교적측정이 용이하다. 그러나 주파수의 왜곡 또는 짧은 시간동안 불규칙하게 발생하는 문제들을 신경망에 그대로 적용하기에는 어려움이 있다. 이러한 신호를 분석하기 위해서는 각 문제들이 갖는 고유한 특징 벡터가 필요하다. 이 특징량은 시간에 따라 변화하지 않고 일정한 값을 가져야 하며 동일한 문제에 대해서는 특징량의 값이 서로 짧은 거리를 가져야 하고 서로 다른 문제에 대해서는 특징량의 거리가 멀어야 한다. 분류학습을 위한 알고리즘의 흐름도는 그림 4와 같다. DWT에서 고역필터를 통과한 세부신호 d_k 검출된 신호의 크기를 갖고 있는 상관계수 k 와 합성된 후 신호왜란의 지속시간을 카운트하고 있는 p 의 검출벡터 연산에 의해 뉴럴학습에 이용된다.

2.3 진단시스템

전력품질 진단시스템의 하드웨어외형은 그림 5와 같다. TI사의 TMS320C6711(150MHz)를 사용하였으며 32MB의 보조메모리와 8MB의 메인 메모리를 내장하였고, RS232C와 USB-2 1포트를 지원한다. 또한 동시 16채널을 12비트, 20Mhz 샘플링 간격으로 읽어서 독립된 4MB의 메모리에 저장한다. 이것을 위해서 DMA 인터럽트를 사용한다. 내부구조는 그림 6과 같다. 아나로그부가 2채널씩 분리되어 각 1개의 FPGA를 거쳐 버퍼메모리에 쌓인다. 버퍼에 저장된 데이터는 메인 DSP부의 DMA 인터럽트 요청에 의해 메인부 메모리에 전송된 후 DWT와 뉴럴네트워크 알고리즘을 수행한다.




그림 5 전력품질 진단시스템 보드사진
Fig. 5 picture of power quality analysis system




그림 6 전력품질 진단시스템 블록도
Fig. 6 Block diagram of power quality analysis system

2.4 전원왜란의 분류

표 1 인식률

Table 1 Recognition rate

True Class	Recognition rate
Micro-Interruption	94%
Spake	92%
Oscillatory	89%
Total	92.7%

시험과형은 각각 20종류로 세분화시켜 20,000번의 학습과정을 통해 네트워크의 상태를 결정하는 연결강도를 조정하였다. 표 1은 상기 시스템의 인식률을 나타낸다. Micro-Interruption에서는 94% Spake에서는 92% Oscillatory에서는 89%로써 평균 92.7%의 인식률을 갖는다.

3. 결 론

본 논문에서는 빠른 주기를 갖고 있는 Transient 신호를 검출하고 분류하는데 보다 정확하게 진단 할 수 있는 알고리즘과 하드웨어를 제안하였다. 이것을 위하여 웨이

블릿변환의 장점을 이용 짧은 지속시간을 갖는 과도상태에서도 정확히 검출할 수 있는 방법과, 진단을 위한 다층퍼셉트론 알고리즘을 적용하였다. 학습벡터에 사용된 아이템은 가능한 그 종류를 줄여 전원왜란에 직접적인 영향을 주는 전압의 크기와 지속시간만을 입력패턴으로 사용하여 불필요한 연산시간과 여기에 따른 오류 판단을 줄여 줌으로써 보다 정확한 분류가 가능 하도록 하였다.

[참 고 문 헌]

- [1] Leopoldo Angrisani and Pasquale Daponte, "Wavelet Network-Based Detection and Classification of Transients", *IEEE Inter. Conf. Transactions on Instrumentation and measurement*, vol. 50, pp. 1425-1435, 2001.
- [2] Dolores Borrás, M.Castilla and Narciso Moreno and J.C Montano, "Wavelet and Neural Structure: A new Tool for Diagnostic of Power System Disturbances", *IEEE Inter. Conf. Transactions on Industry Applications*, vol. 37, pp. 184-190, 2001.
- [5] 김홍균, 이진목, 최재호, "인터넷을 이용한 전력품질진단시스템", *대한전기학회 전력기술 부문회 추계학술대회논문집*, pp. 23-26, 2002.